

**SVEUČILIŠTE U SPLITU
POMORSKI FAKULTET**

NIKŠA OSTOJIĆ

UVOD U EKSPERTNE SUSTAVE

ZAVRŠNI RAD

SPLIT, 2019.

**SVEUČILIŠTE U SPLITU
POMORSKI FAKULTET**

**STUDIJ: POMORSKE ELEKTROTEHNIČKE I INFORMATIČKE
TEHNOLOGIJE**

UVOD U EKSPERTNE SUSTAVE

ZAVRŠNI RAD

MENTOR:

mr. sc. Ivica Kuzmanić

STUDENT:

**Nikša Ostojić
(MB:0023088391)**

SPLIT, 2019.

SAŽETAK

Ekspertni sustavi su sustavi koji, u suštini, oponašaju znanje eksperta. Sastoje se od baze podataka, mehanizma zaključavanja i korisničkog sučelja. Na razvoju ekspertnih sustava, koji traje ponekad godinama, radi čitav niz stručnjaka. Ekspertni sustavi dizajniraju se na način da odgovaraju na potrebe prosječnih korisnika, da olakšavaju rad i poboljšavaju produktivnost. Ekspertni sustavi imaju veliki utjecaj na daljnji razvoj upotrebe računala na brodovima. Najrazvijeniji su ekspertni sustavi koji pomažu u dijagnozi kvarova brodskih motora i olakšavaju cjelokupno upravljanje brodskim pogonom.

Ključne riječi: umjetna inteligencija, inteligentni sustavi, ekspertni sustavi, baza podataka

ABSTRACT

Expert systems are systems that, in essence, mimic the expertise of experts. It consists of a database, a lock mechanism, and a user interface. On the development of expert systems, this lasts for years, a whole series of experts work. Expert systems are designed to meet the needs of average users, to facilitate work and improve productivity. Expert systems have a major impact on the further development of computer use on ships. The most developed are expert systems that help diagnose marine engine failures and make it easier for the entire ship-operated operation.ki

Key words: artificial intelligence, intelligent systems, expert systems, databases

SADRŽAJ

1.	UVOD	1
2.	EKSPERTNI SUSTAVI.....	3
2.1.	POJMOVNO ODREĐENJE I KARAKTERISTIKE EKSPERTNIH SUSTAVA.	4
2.2.	OSNOVNE KOMPONENTE EKSPERTNIH SUSTAVA	Pogreška! Knjižna oznaka nije definirana.
2.2.1.	Razvojno sučelje	9
2.2.2.	Mehanizam zaključivanja.....	10
2.2.3.	Baza podataka i baza znanja	11
2.2.4.	Korisničko sučelje	12
2.3.	RAZVOJ I IZGRADNJA EKSPERTNIH SUSTAVA	Pogreška! Knjižna oznaka nije definirana.
2.3.1.	Izgradnja znanja i softvera.....	15
2.3.2.	Programski jezici i alati za izradu ekspertnih sustava	16
2.3.3.	Razvoj kroz ažuriranja	18
3.	PRIMJENA EKSPERTNIH SUSTAVA U POMORSKOM PROMETU	20
3.1.	PODRUČJA PRIMJENE EKSPERTNIH SUSTAVA U POMORSTVU	20
3.2.	NAJZNAČAJNIJI EKSPERTNI SUSTAVI NA BRODOVIMA	23
4.	ZAKLJUČAK.....	27
	LITERATURA.....	29

1. UVOD

Osnova svakog inteligentnog i ekspertnog sustava je umjetna inteligencija (eng. *Artificial Intelligence*). To je dio područja tehničkih znanosti, tehničkog polja računalnih znanosti, (informatike) koje se bavi razvojem sposobnosti računala da obavljaju zadaće za koje je potreban neki oblik inteligencije. Ekspertni sustav temeljen na umjetnoj inteligenciji može se promatrati kao jedan od tipova informacijskih sustava.

Umjetna inteligencija je usko vezana s pojmom znanja. Ona obuhvaća prikupljanje znanja, njegovu pohranu u posebnim strukturama nazvanim baze znanja i primjene tog znanja pri rješavanju složenih zadataka [1].

Umjetna inteligencija je znanstveno područje, koje ima cilj da strojevi, kao što su računala, imaju sposobnost inteligentnog ponašanja. Vještačka inteligencija je dio znanosti o računalima usmjerena na stvaranje i proučavanje računalnih programa koji ispoljavaju svojstva koja se identificiraju kao inteligentna u ljudskom ponašanju: znanje, zaključivanje, učenje, rješavanje problema, razumijevanje jezika i dr. [2].

Stupanj inteligentnosti sustava procjenjuje se na temelju dominacije umjetne inteligencije u njemu. Jako inteligentni sustav u tolikoj je mjeri razvijen da može razmišljati na istoj razini kao i čovjek. Slabo inteligentni sustav je onaj kojem se mogu pripisati tek neka inteligentna svojstva, npr. mogućnost prepoznavanja govora [1].

Sveukupnost procesa izgradnje ekspertnog sustava naziva se inženjerstvo znanja, time se obuhvaća skup metoda i postupaka koje se odnose na prikupljanje, računalno predstavljanje i memoriranje, kao i upotrebu ljudskog znanja u rješavanju složenih problemskih situacija. Taj proces uključuje posebnu vrstu interakcije između graditelja ekspertnog sustava, koga zovemo inženjer znanja i jedne ili više osoba koje su eksperti u određenom problemskom području za koje se ekspertni sustav

izgrađuje. Inženjer znanja od eksperata prikuplja znanja o izvršenjima procedura, strategija i postupaka za rješavanje problema i ugrađuje to znanje u ekspertni sustav. Rezultat procesa je skup programa koji rješavaju probleme u datom području na način na koji to radi čovjek-ekspert [3].

Cilj ovog završnog rada je prikazati teorijske osnove ekspertnih sustava i njihovu primjenu u pomorstvu. Radi cjelovitijeg uvida u temu rad je podijeljen na dva dijela. U prvom dijelu rada definirani su ekspertni sustavi i prikazane su njihove najznačajnije karakteristike. Nadalje, prikazane su i osnovne komponente ekspertnih sustava – razvojno sučelje, mehanizam zaključavanja, baza podataka i baza znanja te korisničko sučelje. Za bolje razumijevanje razvoja ekspertnih sustava opisani su programski jezici i alati za izradu ekspertnih sustava, podloge za izgradnju i njihov razvoj kroz ažuriranja. Drugi dio rada prikazuje primjenu ekspertnih sustava u pomorstvu i najznačajnije inteligentne sustave koji su nezaobilazni u suvremenom pomorskom prometu i upravljanju održavanja brodova.

2. EKSPERTNI SUSTAVI

Ideja kompjuterizacije pojavila se tridesetih godina 20. stoljeća. Rađanje umjetne inteligencije, kao posebne znanstvene discipline dogodilo se 1956. godine kada je organizirana dvomjesečna radionica na kojoj je skup 10 ljudi koji su se bavili teorijom automata, neuronskim mrežama i istraživanjem inteligencije prihvatio prijedlog da se novo područje istraživanja nazove umjetna inteligencija.

Deset godina kasnije započinje faza realnosti sustava temeljenih na znanju, a od 1980. godine započinje i primjena ekspertnih ulaskom inteligentnih sustava u područje industrije.

Danas se pouzdano ne zna koliko je izgrađeno specifičnih programa. Još uvijek se najveći broj ekspertnih sustava razvija i koristi u okvirima najvećih i najpoznatijih sveučilišnih ustanova tehnološki najrazvijenijih zemalja svijeta. Zbog svoje velike praktične primjene podliježu strogoj kontroli i nedostupni su široj javnosti. [2]

Današnji stupanj razvoja moderne informatičke nauke sve više omogućava da se stalno može raspolagati ekspertnim uslugama. Danas se ekspertni sustavi koriste gotovo u svim područjima i rade sve ono za što se smatra da čini čovjekovu inteligenciju. Komponente ekspertnih sustava generiraju tri glavna zadatka inženjerstva znanja. To su:

- prezentacija i pohrana velikih količina znanja problemskog područja,
- aktiviranje uporabe znanja za rješavanje problema i
- pružanje odgovora na korisnička pitanja.

Tri su osnovna smjera istraživanja i razvoja inteligentnih sustava koji su entiteti distribuirane umjetne inteligencije. To su: rješavanje zadataka sa ciljem prilagodbe koncepta, rješavanje zadataka nezavisnim entitetima i simulacije kod kojih se modeliraju pojedini entiteti a cijeli se model temelji na interakciji mnoštva entiteta. [1]

2.1. POJMOVNO ODREĐENJE I KARAKTERISTIKE EKSPERTNIH SUSTAVA

U literaturi se može naći veći broj sličnih definicija. Ekspertni sustav je inteligentni računalni program koji koristi znanje i postupke zaključivanja u procesu rješavanja problema i to takvih problema za čije je rješavanje potreban visok stupanj stručnosti i iskustva iz područja kojima je ekspertni sustav namijenjen. Naziv potječe upravo od toga što se ovi sustavi ponašaju kao vrhunski stručnjaci (eng. *expert*) na svom području. Njegovu osnovu čini poseban *software* koji modelira one elemente čovjekovog rješavanja problema za koje se smatra da čine čovjekovu inteligenciju: zaključivanje, prosuđivanje, odlučivanje na osnovu nepouzdatih i nepotpunih informacija i tumačenje svog ponašanja.

Karakteristika ekspertnih sustava je brzo i točno djelovanje, objašnjavanje i davanje odgovora na temelju teorije ili prema heurističkim pravilima, tj. pozivajući se na već zapamćene slučajeve iz prošlosti. Ekspertni sustavi, također, imaju sposobnost izravnog informiranja korisnika koji postavlja pitanja. Ekspertni sustav za dijagnostiku stanja brodskoga dizelskog motora temelji se na eksperimentalnim podacima dobivenima mjerenjem relevantnih značajki brodskog motora i kontinuiranim praćenjem njegova rada. [4]

Ekspertni sustavi imaju za cilj osigurati odgovor na probleme koji zahtijevaju rasuđivanje, prepoznavanje i usporedbu oblika, akviziciju novih koncepata, zaključivanje, ukratko, oni daju odgovor na pitanja koja zahtijevaju inteligenciju. Ovi sustavi se mogu efikasno primjenjivati u područjima gdje se mišljenje o problemu svodi na logičko rasuđivanje, a ne na izračunavanje, te u područjima gdje svaki korak u rješavanju problema ima veći broj alternativnih mogućnosti. [2]

Ekspertni sustavi posjeduju niz korisnih svojstava. Stručnost je dostupna na svakom računalu primjerenih performansi, Moglo bi se zapravo reći da je ekspertni sustav jedan način masovne proizvodnje stručnosti. Također, cijena pružanja stručnosti po korisniku je znatno snižena.

Ekspertni sustavi mogu biti korišteni i u okruženjima koja mogu biti potencijalno opasna po ljudsko zdravlje stoga osiguravaju sigurniji način obavljanja posla.

Stručnost je trajna i za razliku od ljudskih stručnjaka koji mogu otići u mirovinu, dati otkaz ili umrijeti, znanje i stručnost ugrađeni u ekspertni sustav ne posjeduju rok trajanja. Pomoću ekspertnih sustava znanje većeg broja stručnjaka može biti iskorišteno da istovremeno i neprekidno radi na rješavanju problema u bilo koje doba dana i noći. Razina stručnosti većeg broja stručnjaka znanjem i opširnošću znatno nadmašuje znanje samo jednog stručnjaka.

Ekspertni sustavi povećavaju pouzdanost u donošenje pravilne odluke pružajući drugo mišljenje ljudskom stručnjaku ili mogu pomoći u donošenju odluke u slučaju kada se veći broj ljudskih stručnjaka ne može usuglasiti oko rješenja. Naravno, ova metoda vjerojatno nije primjenjiva ako je jedan od tih stručnjaka programirao sam ekspertni sustav budući bi se, ukoliko stručnjak nije počinio nekakvu pogrešku, ekspertni sustav uvijek trebao slagati sa stručnjakom na bazi čijeg znanja je oformljen.

Ekspertni sustav može eksplicitno u detalje objasniti razmišljanje koje ga je dovelo do nekog zaključka. Ljudski stručnjak bi možda bio preumoran, u nemogućnosti ili bi nevoljko to radio cijelo vrijeme i uvijek kada je potrebno. Ovo povećava pouzdanje u ispravnost donesene odluke. Brza ili reakcija u stvarnom vremenu može nekad biti krucijalna za neka područja primjene. Ovisno o korištenom *software-u* i *hardware-u*, ekspertni sustav može odgovarati na upite brže i spremnije od ljudskog stručnjaka. Neke hitne situacije možda zahtijevaju reakciju bržu nego što ju je ljudski stručnjak u mogućnosti pružiti pa se u takvim slučajevima ekspertni sustavi sa reakcijom u stvarnom vremenu nameću kao dobro rješenje.

Ekspertni sustavi pružaju uravnotežene, kompletne reakcije bez prisutnosti osjećaja. Ovo svojstvo je potencijalno izrazito bitno u stvarnim stresnim situacijama ili hitnim slučajevima kada ljudski stručnjak možda nije u mogućnosti djelovati pri vršnoj učinkovitosti kao posljedica stresa ili umora.

Ekspertni sustav može se koristiti i kao inteligentni sustav za učenje koji omogućava učeniku pokretanje i proučavanje primjera te ujedno i objašnjava način razmatranja sustava prema određenim primjerima. Ekspertni sustavi mogu biti korišteni za pristup bazi podataka na inteligentan način.

Ovisno o sustavu, načini objašnjavanja i razlaganja donesenih odluka mogu biti jednostavni ili složeni. Jednostavni sustavi u pravilu samo navode činjenice koje su ih zaključivanjem doveli do posljednjeg izvedenog pravila. Složeniji sustavi su sposobni učini i nešto od sljedećeg:

- Navesti sve razloge za i protiv određene hipoteze,
- Navesti sve hipoteze koje mogu objasniti dostupne dokaze,
- Objasniti sve posljedice hipoteze
- Dati prognozu ili predviđanje što će se dogoditi u slučaju da je hipoteza ispravna
- Opravdati pitanja koja program postavlja korisniku kako bi dobio dodatne informacije
- Opravdati znanje programa. [2]

Najčešći problemi koji se mogu pojaviti u nekom ekspertnom sustavu su:

- Nedostatak određenih parametara,
- Neadekvatni odnosi ili utjecaji parametara na krajnji rezultat,
- Nepostojanje nekih "među rezultata" tj. Pomoćnih informacija. [1]

Ekspertni sustavi mogu biti temeljeni na pravilima (eng. *Rule Based Systems*) i sustavi koji se temelje na učenju (eng. *Inductive Learning Systems*). Mogući su i mješoviti sustavi koji dio znanja stječu putem dobivenih pravila, a dio putem pravila koja sami izvide učeći na primjerima.

2.2. OSNOVNE KOMPONENTE EKSPERTNIH SUSTAVA

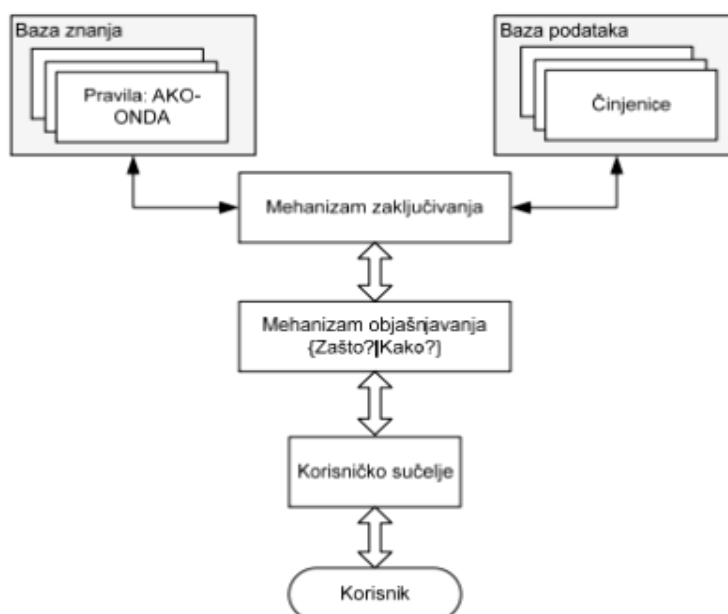
Iskustva u izgradnji ekspertnih sustava ukazala su na brojne mogućnosti stjecanja novih znanja iz raspoloživih dijelova ekspertnih sustava, baza znanja i baza podataka. [1]

Osnovne komponente ekspertnih sustava su komunikacijski među sklopovi, mehanizam (modul) zaključivanja, baza podataka i baza znanja.

Izgradnja ekspertnog sustava započinje analizom i specifikacijom zahtjeva za bazu znanja (eng. *knowledge base*) i bazu podataka (eng. *data base*). Ovoj aktivnosti potrebno je posvetiti posebnu pažnju, kako bi točno definirane potrebe u startu izrade aplikacija i baza podataka i baza znanja osigurale njihovu konačnu primjenu. Odabirom učećeg agenta, postavljen je cilj na ekspertni sustav da djeluje u okružju koje je njemu na početku nepoznato, pa kako stječe više znanja tako je i njegovo djelovanje bolje i sigurnije, a za to su potrebni elementi za učenje (eng. *learning element*), izvedbeni elementi (eng. *performance element*), ocjenjivač (eng. *critic*) i generator zadatka (eng. *problem generator*).

Model podataka potrebno je napraviti u važećim dijagramskim standardima takvim da se može nadograđivati u skladu s potrebama korisnika. Također u fizičkom modelu, tj. na propisanoj platformi predvidjeti mogućnost nadograđivanja baze podataka, kako njenih relacija tako i korisničkih sučelja (formi).

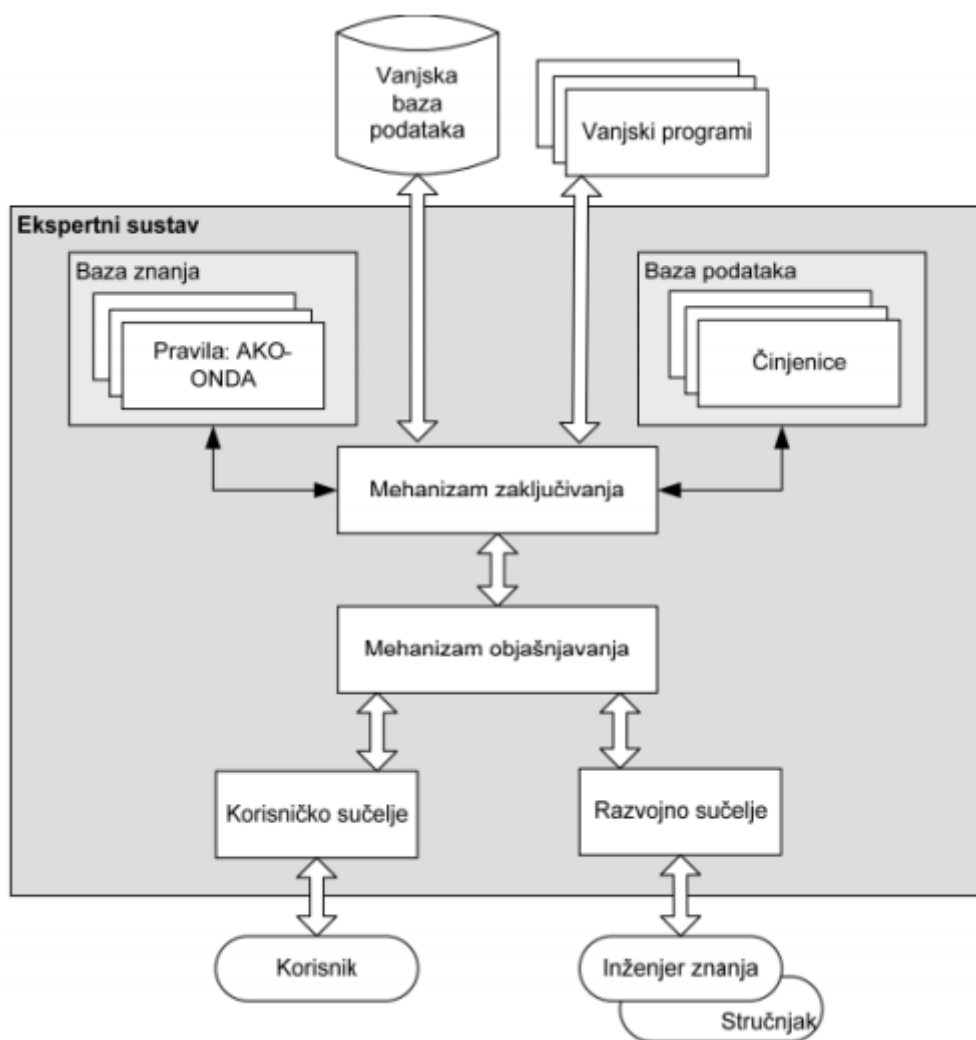
Koncept ekspertnog sustava prikazan je na slici 1. Nakon što se specificira problem, utvrđuju se zahtjevi potrebni da se dođe do informacija. Podaci se dobivaju iz odgovarajućih izvora i adekvatno se organiziraju u bazi ulaznih podataka. Slijedi izrada modela problema sa shemom procesa koji vodi do rješenja. [4]



Slika 1. Jednostavan prikaz koncepta ekspertnog sustava [5]

Potrebno je napraviti konceptualni, logički i fizički model baze podataka. Također je potrebno definirati forme za unos i pregled podataka u bazi, kao i oblike izvješća imajući na umu jednostavnost korisničkoga sučelja, koje je potrebno projektirati uz validacije unosa podataka. [1]

Arhitektura ekspertnih sustava ili na znanju temeljenih sustava nije značajnije mijenjana i više je poznatih problema u njihovu razvoju. Prikupljanje znanja vrlo je težak i dugotrajan proces, implementacija i uspješno korištenje ovakvih sustava zahtijeva visoku stručnost i iskustvo. Implementirani ekspertni sustavi često su spori i teški za održavanje.



Slika 2. Detaljan prikaz koncepta ekspertnog sustava [5]

Ekspertni sustavi sadrže i bazu podataka čime se mogućnosti sustava znatno proširuju i povećavaju. Suvremeni ekspertni sustavi imaju mogućnost prikupljanja znanja i učenja. Razvojni dio ekspertnih sustava zadužen je za prikupljanje znanja koje je moguće tzv. strojnim učenjem ili preuzimanjem znanja od stručnjaka. Prikupljanje znanja kod ovakvih sustava u svakom je slučaju vrlo teško i zahtijeva tzv. eksperte za prikupljanje znanja. Modul za učenje u suvremenim ekspertnim sustavima važan je dio koji omogućuje tzv. samoučenje sustava. Glavni problemi ekspertnih sustava jesu nedostatak tzv. dubokog znanja, zatim točnost rezultata i skupo učenje. Nedostatak “dubokog znanja” ustvari znači čest nedostatak uskih specijalističkih znanja za uspješno rješavanje problema.

Proces objašnjenja postupka zaključivanja također je često nerazumljiv. Točnost rezultata često može biti upitna. Ovo je ozbiljan problem, posebno u rizičnim područjima kao što je upravljanje zračnim prometom, upravljanje nuklearnim pogonima, vojnim sustavima itd.

2.2.1. Razvojno sučelje

Razvojno sučelje naziva se još i modul za prikupljanje znanja. Proces prikupljanja znanja i njegove transformacije u izabranu formu za predstavljanje naziva se inženjerstvo znanja, a stručnjaci koji taj posao obavljaju nazivaju se tehnolozi znanja. [5]

Proces prikupljanja i inoviranja znanja može se obaviti na tri načina.

- Ručno uz posredovanje tehnologa znanja (konzultiranjem stručnjaka-eksperata).
- Ručno, ali bez posredovanja tehnologa znanja. U razvoju novijih ekspertnih sustava teži se ovakvom načinu prikupljanja znanja, pa se razvijaju i odgovarajući alati za akviziciju. To su softverski moduli koji moraju biti sofisticirani s obzirom da ekspert područja ne mora posjedovati mnogo znanja iz računalne znanosti.
- Automatsko učenje, kao najviši oblik inoviranja znanja temelji se na generalizacijama i induktivnom učenju stroja na osnovi poznatog primjera iz

prošlosti Na ovim tehnikama obavljaju se intezivna istraživanja bazirana prije svega na metodama i tehnikama automatskog učenja i kvalitativnog modeliranja.

Opća forma za predstavljanje znanja treba omogućiti zapis znanja iz problemske domene, što uključuje činjenice o karakteristikama objekta, relacije među njima, opća pravila i metode za rješavanje problema o tom području.

Shema predstavljanja znanja (formalizam) se smatra prikladnim za upotrebu u ekspertnim sustavima ako omogućuje efikasno rješavanje problema i istovremeno je pogodan za jednostavnu verifikaciju, modifikaciju i dopunjavanje baze znanja. Za predstavljanje znanja koriste se razne sheme (formalizmi): produkcijska pravila, semantičke mreže, okviri, predikatni račun i dr. [1]

2.2.2. Mehanizam zaključivanja

Mehanizam zaključivanja (eng. *Inference Mechanism*) je *software* sposoban na osnovu pravila iz baze znanja shvatiti informacije iz baze znanja i na osnovu toga izvoditi zaključke. On funkcionira na taj način da činjenice iz baze znanja kombinira sa informacijama dobivenim od korisnika u cilju izvođenja specifičnih zaključaka. Pri radu se koriste kontrolne strategije koje odlučuju u kojem trenutku treba primijeniti neko od pravila iz baze znanja na nove činjenice dobivene tijekom konzultiranja sa korisnikom. Na taj način se simulira ljudsko razmišljanje.

Postoje dvije osnovne procedure zaključivanja, odnosno rezoniranja:

- Zaključivanje koje počinje s tzv. potvrđenim pronalascima i djeluje unaprijed da pronađe zaključak, tzv. zaključivanje vođeno podacima (eng. *Forward chaining*),
- Zaključivanje koje počinje s hipotezom i djeluje unatrag prema lako potvrđenim pronalascima, tzv. zaključivanje vođeno ciljem (eng. *Backward chaining*).

2.2.3. Baza podataka i baza znanja

Ključni faktor za dobre performanse ekspertnih sustava je kvaliteta znanja koje je u njega ugrađeno. Znanje se čuva u bazi znanja ekspertnih sustava [2].

Baza znanja (eng. *Knowledge Base* – KB) je baza činjenica i heuristika pridruženih problemu u području za koje je namijenjen ekspertni sustav. Baza znanja uključuje činjenice, relacije između činjenica i moguće metode za rješavanje problema u području date aplikacije. U predstavljanju znanja koriste se tzv. proizvodna pravila, okviri i semantičke mreže. Prikupljanje znanja vrši se intervjuiranjem stručnjaka i tzv. strojnim učenjem. Baze znanja, dakle, u najjednostavnijem smislu mogu se shvatiti kao mjesta pohrane znanja u bilo kojem obliku, ne nužno digitalnom, iako je to najčešći slučaj. [2] [7]

Izgradnja ekspertnog sustava započinje analizom i specifikacijom zahtjeva za bazu znanja i bazu podataka. Ovoj aktivnosti potrebno je posvetiti posebnu pažnju, kako bi točno definirane potrebe u startu izrade aplikacija i baza podataka i baza znanja osigurale njihovu konačnu primjenu.

Model podataka potrebno je napraviti u važećim dijagramskim standardima takvim da se može nadograđivati u skladu s potrebama korisnika. Također u fizičkom modelu, tj. na propisanoj platformi predvidjeti mogućnost nadograđivanja baze podataka, kako njenih relacija tako i korisničkih sučelja (formi). Potrebno je napraviti konceptualni, logički i fizički model baze podataka. Također je potrebno definirati forme za unos i pregled podataka u bazi, kao i oblike izvješća imajući na umu jednostavnost korisničkoga sučelja, koje je potrebno projektirati uz validacije unosa podataka.[1]

Baze znanja mogu prikazivati znanja kao:

- predikate – formalna logika (engl. *formal logic*) je tehnika koja predstavlja informacije na način da je lako provjeriti je li informacija točna ili nije.
- semantičke mreže – grafove koji predstavlja objekte (događaji ili akcije) i sadrži realna značenja o objektima.
- okvire znanja (engl. *frames*) – simbolički predstavljaju znanje.

- sadrže pretince (engl. *slots*) koji sadrže informacije, a pretinci sadrže pokazivače na druge pretince ostalih okvira i tako se znanje povezuje u smislenu cjelinu.
- pravila (engl. *rules*) – predstavljaju znanje prema kondicionalnom modelu "IF-THAN. [1]

Baza znanja sadrži objekte i relacije među njima, činjenice i nesigurne činjenice, pravila svijeta i pravila odlučivanja, opise motivacije, cilja i stanja sustava, metode rješavanja problema i heuristiku, opis ponašanja, hipoteze opise tipičnih situacija, procese, ograničenja, metaznanje, znanje iz problemske domene, znanje o načinu kako se problem rješava i dr. [5]

2.2.4. Korisničko sučelje

Korisničko sučelje (eng. *User Interface* – UI) je dio koji omogućava dijalog između donosioca odluke (korisnika) i sustava. Služi za unos i prikaz podataka, prezentira moguće odluke, prikazuje informacije, pitanja, odgovore te odvrća korisnika da unosi greške. Sa jedne strane omogućava korisniku da tijekom rada sustava dostavi informacije koje sustav iz baze znanja nije uspio dobiti, a sa druge strane omogućava korisniku da za svaku odluku ekspertnog sustava zatraži dodatno objašnjenje o tome koji su ga zaključci vodili da donese takvu odluku odgovaranjem na pitanja.

Korisničko sučelje ima funkciju punjenja baze znanja novim faktima, te funkciju korištenja ekspertnog sustava od strane ne-eksperta. Korisničkim sučeljem korisnik pristupa pojedinim dijelovima ekspertnog sustava i konfigurira ga. Stoga ono mora omogućiti lak i razumljiv pristup upotrebi i prilagođavanju dijelova ekspertnog sustava ne ulazeći pri tom, u samu kompleksnost ekspertnog sustava. Danas se to postiže korištenjem multimedijalne sposobnosti računalnih sustava. To se postiže kroz tehnologiju aktivnih dokumenata koji omogućuju spajanje multimedijalnih sadržaja, koji opisuju neki koncept i upravljaju njime.

Moguća su i rješenja korištenjem tehnologije inteligentnih sučelja, koje su i same oblik umjetne inteligencije kao i ekspertni sustavi. Njih je teže razviti, ali već postoje

na tržištu standardizirana inteligentna sučelja koja uvelike olakšavaju posao jer ih je potrebno samo prilagoditi ili popuniti podacima.

Među takva sučelja mogu se ubrojiti svi računalni "agenti" koji se kao alati mogu koristiti u svojim aplikacijama, pa tako i u ekspertnom sustavu. Navedene tehnologije navode korisnika kroz proces prilagođavanja ili ažuriranja objašnjavajući svaki korak u procesu.

Prilikom izgradnje ekspertnog sustava potrebno je voditi računa o prilagođavanju korisničkog sučelja sposobnosti i spremnosti prosječnog korisnika da može koristiti ponuđene opcije. Ovo je ključno za određivanje raspona kontrole nad pojedinim dijelovima ekspertnog sustava koji će se dati korisniku, odnosno određenje kontrole koja će ipak biti ostavljena u rukama razvojnog tima ne gubeći pri tom prvotne ciljeve.

Korisničko sučelje, tj. forme za unos, pregled i izmjenu podataka te forme izvješća moraju biti definirane tako da čuvaju integritet baze podataka, preko validacije i programskih ograničenja operacija s bazom podataka ali i da omoguće jednostavan rad korisniku. Forma korisničkog sučelja neke baze za unos podataka padajućim menijima pomaže lakšem unosu novih podataka i njihovoj validaciji na način da se koriste izvedeni programski filtri. Npr. za odabrano područje u padajućem izborniku se dobivaju objekti samo iz tog područja.

Glavne značajke tako formiranog ekspertnog sustava su:

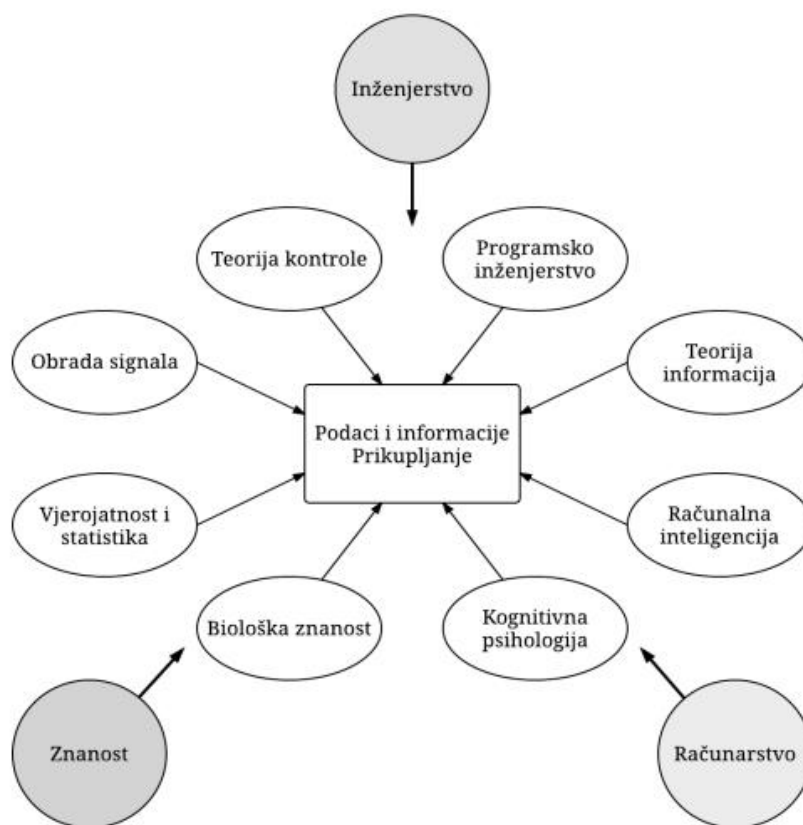
- jednostavno dodavanje nekih novih znanja,
- fleksibilna strategija rješavanja problema,
- visoki stupanj rješavanja problema,
- mogućnost objašnjenja što je napravljeno i zašto je napravljeno. [1]

Mogu se izdvojiti tri glavne skupine korisnika ekspertnih sustava: krajnji korisnik, stručnjak domene i inženjer znanja. Korisnik upotrebljava ekspertni sustav za rješavanje problema kao pomoć pri odlučivanju. Stručnjak domene i inženjer znanja sudjeluju u izgradnji i održavanju sustava. Stručnjak iz određenog područja za koje se sustav izrađuje gradi sustav i snabdijeva bazu znanja koristeći svoje znanje i iskustvo, te inženjer koji pomaže stručnjaku u prikazu njegovog znanja, unosi znanje

u modul objašnjavanja i definira sučelje i tehnike potrebne za izvođenje zadovoljavajućeg programa za ekstrakciju rješenja problema. [7]

2.3. RAZVOJ I IZGRADNJA EKSPERTNIH SUSTAVA

Da bi se razvio jedan kvalitetan ekspertni sustav potrebno je jako puno rada i vremena. To je proces koji traje godinama. Jedan od razloga zašto se u razvoju stručnih sustava pojavljuju ozbiljni problemi je proces mijenjanje, (ažuriranja) činjenica odnosno znanja. Dinamična okolina unutar koje stručni sustav mora funkcionirati nameće na njega dva zahtjeva: ažuriranje i prilagodljivost pojedinom stručnom korisniku [1].



Slika 3. Grafički prikaz multidisciplinarnog pristupa u izgradnji ekspertnih sustava [1]

Ekspertne sustave razvijaju čitavi timovi stručnjaka, koristeći sva navedena područja nauke i tehnike. Za razmatranje arhitekture ekspertnih sustava se može uzeti

minimum stručnjaka, koji su u stanju sačiniti ekspertni sustava. Taj minimum se sastoji od: specijaliste iz područja kojem je namijenjen ekspertni sustav – eksperta i specijaliste za organizaciju i realizaciju sustava, koji u sebi objedinjuje organizatora baze znanja i sistemskog inženjera za *software*. Taj specijalista se može uvjetno nazvati inženjer znanja. Osnovna shema ekspertnog sustava je nezamisliva bez korisnika, jer ekspertni sustav ima smisla samo ako se može praktično primijeniti. Testiranje ekspertnih sustava, u svim fazama razvoja, se provodi uz pomoć korisnika [2].

Često se mehanizam zaključivanja i korisničko sučelje zajednički nazivaju ljuskom ekspertnog sustava. Tako se sugerira da se ekspertni sustav sastoji od znanja o domeni (baza znanja) i generičkih postupaka za njegovu primjenu. Prednost takve podjele je u tome što je ljuska načelno neovisna o domeni ekspertnog sustava. Ista ljuska bi se u takvoj organizaciji mogla koristiti u različitim ekspertnim sustavima, u kombinaciji sa prikladnim bazama znanja. Naravno, sve baze znanja u tom slučaju moraju biti izvedene u skladu s formalizmom koji propisuje ljuska što u praksi može prouzročiti probleme.

Opći plan razvoja ljuske ekspertnog sustava se stoga sastoji od slijedećih koraka:

1. Izbor formalizma za prikaz znanja;
2. Definiranje mehanizma zaključivanja, u skladu s odabranim formalizmom;
3. Razvoj korisničkog sučelja;
4. Dodavanje podrške za zaključivanje na temelju nepotpunog, nesigurnog ili neizrazitog znanja. [15]

2.3.1. Izgradnja znanja i softvera

Potrebne su i tehničke vještine i vještine rada s ljudima kako bi se od eksperata uspješno prikupilo znanje bitno za ekspertni sustav. Nekada je potrebno prepoznati bitno, zatražiti objašnjenje ili iz ispričanog moći složiti strukturu znanja. Ponekada eksperti, iako raspoložu znanjem teže ga prenose jer se znanje ne odnosi na baratanje nekom činjenicom već ovisi o intuiciji ili osjećaju za posao.

Postoje *software*-ski alati namijenjeni intervjuiranju eksperata koji funkcioniraju na način da se istovremeno unose pravila i demonstrira ekspertu kako će izgledati kada se pravila primijene. Tako ekspert može odmah komentirati ukoliko se pojavi mogući propust. U primijenjenoj metodologiji upravljanja znanjem pri razvoju ekspertnih sustava mogu se izdvojiti tri glavne aktivnosti: prikupljanje, analiza i modeliranje znanja te verifikacija znanja.

Izgradnja *software*-a ekspertnog sustava koristi se primjenom metoda softverskog inženjerstva. Po potrebi se može odabrati neka tradicionalna metoda, prototipiranje, inkrementalna metoda ili neka druga koja najbolje odgovara značajkama projekta. [3]

2.3.2. Programski jezici i alati za izradu ekspertnih sustava

Programski jezik je određen skupom simbola i pravilima njihovog slaganja kojim se opisuje postupak računanja. Opis računanja u danom programskom jeziku interpretira, odnosno tumači, stroj koje nazivamo računalo. Poznati sinonimi za postupak računanja su algoritam i program. Niz simbola, složeni po pravilima programskog jezika, čine jezične izraze (rečenice) tog programskog jezika koji se zatim zapisuju na podatkovni medij i predaje računalu koje na svaki otkucaj sata čita i tumači jedan simbol programa zapisanog na podatkovnom mediju. [12]

Alat za izgradnju ekspertnih sustava je programski jezik koji koristi inženjer znanja i/ili programer kako bi taj sustav izradio. Pod pojmom alat podrazumijevaju se i svi uslužni programi koji su na raspolaganju. Razvijeni su specijalizirani alati za izradu ekspertnih sustava, koji su nazvani "školjke" (eng. *shells*). Ovi alati se razlikuju od konvencionalnih programskih jezika po tome što osiguravaju odgovarajuće načine predstavljanja složenih koncepata i elemenata znanja. [2]

Konvencionalni programski jezici kao FORTRAN ili C su dizajnirani i optimizirani za proceduralnu obradu podataka (npr. brojeva ili polja). Ljudi, međutim, često rješavaju vrlo složene probleme apstraktnim, simboličkim pristupom koji nije prikladan za implementaciju u konvencionalnim programskim jezicima. Iako apstraktne informacije mogu biti modelirane unutar tih programskih jezika, značajan napor je potreban pri

programiranju i pretvorbi ovih informacija u format koji se koristi kod proceduralnih programskih paradigmi.

Jedano od dostignuća istraživanja u području umjetne inteligencije je bio razvoj tehnika koje omogućuju modeliranje informacija na višim razinama apstrakcije. Ove tehnike su sadržane u jezicima ili alatima koji omogućuju izradu programa na način blizak ljudskoj logici te stoga nude lakši pristup pri rješavanju određenih problema. Programe koji emuliraju ljudsku ekspertizu u dobro definiranim problemskim domenama nazivamo ekspertni sustavi. Dostupnost alata za razvoj ekspertnih sustava kao što su JESS i CLIPS, je znatno smanjila napor i trošak vezan uz razvoj ekspertnih sustava.

Razvoj programa temeljem pravila je jedna od najčešće korištenih tehnika za razvoj ekspertnih sustava. U ovoj programskoj tehnici, pravila se koriste za opis heuristike koja određuje set akcija koje se izvode u danoj situaciji. Pravilo se sastoji od IF djela i THEN djela. IF dio pravila je niz uzoraka (uvjeta) koji opisuju činjenice ili podatke koje određuju primjenjivost pravila. Postupak uspoređivanja činjenica sa uzorcima se naziva raspoznavanje uzoraka (eng. *pattern matching*).

Ekspertni sustav pruža mehanizme (eng. *inference engine*) koji automatski uspoređuje činjenice sa uzorcima i određuje koja pravila su primjenjiva. Raspoznavanje uzoraka IF dijela pravila se primjenjuje svaki put kad se dogode promjene u činjenicama odnosno okolnosti promatranog problema. THEN dio pravila je niz akcija koje se trebaju izvršiti kad se utvrdi primjenjivost pravila. Akcije primjenjivog pravila se izvršavaju kad se sustavu signalizira početak izvršavanja. Tada sustav odabire pravilo i akcije odabranog pravila bivaju izvršene. Rezultat ovog izvršavanja akcija može utjecati na primjenjiva pravila dodavanjem novih ili uklanjanjem starih činjenica, Nakon toga odabire se novo pravilo i njegove akcije se izvršavaju. Ovaj postupak se nastavlja dok sustav nalazi primjenjiva pravila. [14]

2.3.3. Razvoj kroz ažuriranja

U početnim fazama razvoja, prikuplja se znanje na osnovi kojeg će ekspertni sustav raditi. U kasnijim fazama to se znanje usavršava, nadopunjava i kontrolira za potrebe stručnog sustava. Zbog ovih činjenica može se dogoditi da ekspertni sustav više ne odgovara stvarnim potrebama korisnika ili daje loše rezultate (koji su tijekom razvoja bili dobri ili povoljni). Već se događalo da su se gotovi ekspertni sustavi bacali u vodu jer su kroz razdoblje razvoja postali beskorisni kao što su primjeri brojnih sustava vojnog karaktera. Drugi vid ažuriranja je nadograđivanje ekspertnih sustava u uporabi.

Kako bi se ekspertni sustav ažurirao, potrebna su nova saznanja na polju djelovanja. Osim dogradnje u postojeći sustav ponekad je neophodno i mijenjati po potrebi određenje dijelove, podsustave ili njihove relacije. Također može se ukazati potreba za uspostavom novih odnosa između novih saznanja i postojećeg znanja ekspertnih sustava za određeno polje struke.

Najčešće je nemoguće napraviti ekspertni sustav koji će u potpunosti odgovarati svim potrebama struke. Zbog različitih preferencija, znanja, potreba, sklonosti i sposobnosti korisnika, i uz najbolji trud razvojnog tima ekspertnog sustava da ga naprave što prihvatljivijim što širem krugu korisnika, često se pojavljuju zahtjevi korisnika za koje je potrebno izraditi posebnu verziju. Takvi su sustavi, personalizirani stručni sustavi. Izrada takvih posebnih verzija normalno iziskuje dodatno vrijeme i troškove razvoja. U takvim se slučajevima nastoji trošak procesa personalizacije ekspertnog sustava prebaciti na samoga korisnika.

Poznavajući funkcioniranje ekspertnog sustava moguće je klasificirati zahtjeve korisnika. Korisnik preko sučelja ekspertnog sustava pokreće mehanizam zaključivanja koji koristi bazu znanja u procesu zaključivanja i daje određene (ekspertne) odgovore. Baze znanja su modeli realnog sustava opisanog parametrima i odnosima među tim parametrima.

Mehanizam zaključivanja selekcionira potrebne parametre, izvlači ih iz baze znanja a pri tom može od korisnika ili na druge načine pribaviti vrijednosti tih parametara.

Parametri se, obrađuju i s obzirom na njihove odnose i po ugrađenim metodama obrade dolazi se do rezultata. [1]

3. PRIMJENA EKSPERTNIH SUSTAVA U POMORSKOM PROMETU

Primjena novih tehnologija na brodu kao što su ekspertni sustavi, neizrazita logika, genetički algoritmi, neuronske mreže, prepoznavanje uzoraka i slično, pruža nove mogućnosti glede upravljanja, dijagnostike stanja, te potpunog vođenja broda kao složenog autonomnog objekata. Ugradnjom inteligencije u sustave nadzora, upravljanja i vođenja brodskih procesa znatno se povećava ukupna pouzdanost i raspoloživost broda kao cjeline.

Ekspertni sustavi su se razvijali usporedno sa razvojem računala, novih računalnih programa i novih spoznaja o održavanju tehničkih sustava. Došli su na razinu jedno jako visoko razvijenog sustava praćenja, prepoznavanja i otklanjanja problema raznih strojeva i uređaja.

Ekspertni sustavi koriste se na više načina:

- Dijagnoza – zaključivanje o uzrocima pogrešnog funkcioniranja sustava na temelju podataka o njegovim značajkama (financijske analize);
- Otklanjanje kvara – način na koji se sustav može dovesti u zadovoljavajuće stanje;
- Predviđanje – zaključivanje o posljedicama određenih situacija (financijska ili demografska predviđanja);
- Oblikovanje – konfiguriranje sustava unutar zadanih ograničenja (oblikovanje budžeta ili računalnog sustava). [6]

3.1. PODRUČJA PRIMJENE EKSPERTNIH SUSTAVA U POMORSTVU

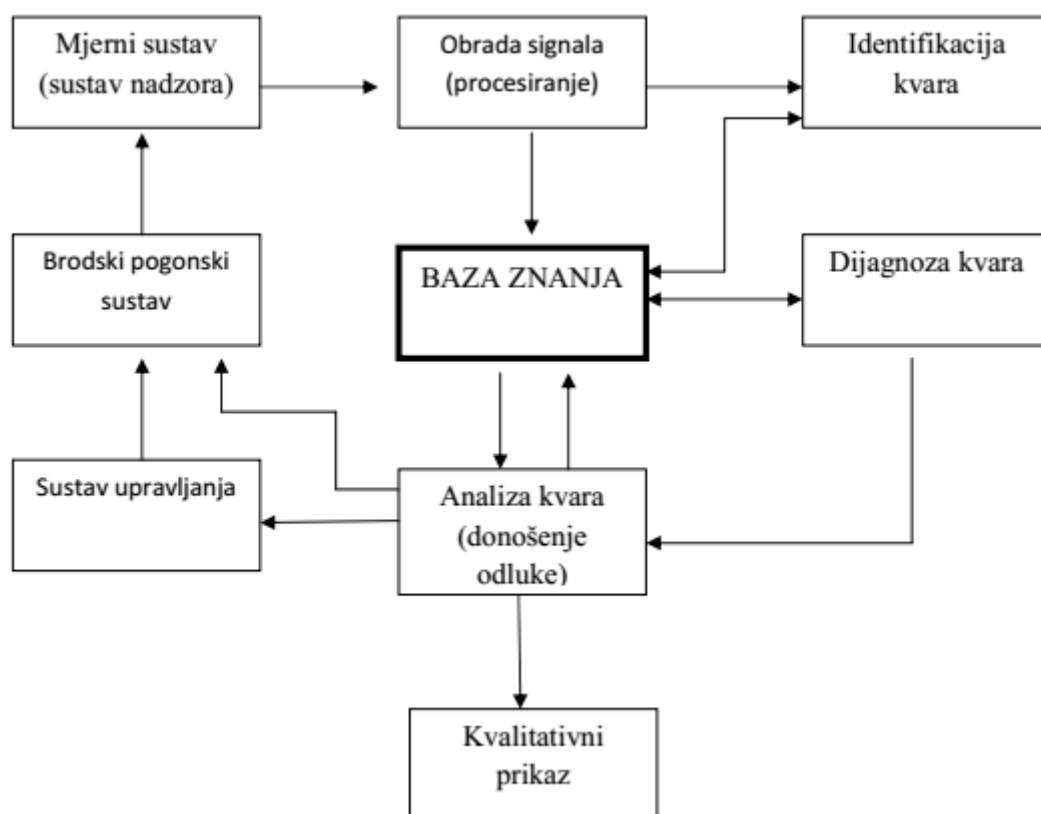
Ekspertni sustavi u pomorstvu prema užem području primjene, odnosno zadatku kojeg rješavaju, mogu se klasificirati u grupe:

- Ekspertni sustav za pomorski transport – planiranje i optimiranje plovniha putova, prijevoznih sredstava, transporta tereta, robe i putnika i slično.

- Ekspertni sustav za podršku u odlučivanju – pomoć i savjeti menadžmentu u donošenju odluka u raznim situacijama kao kod gradnje broda, upravljanje resursima poduzeća, izbor ponuđača i opreme i sličnih stvari.
- Ekspertni sustavi za projektiranje / dizajn - projektiranje brodskih strojeva i uređaja, te aranžiranje opreme na brodu, dizajniranje *offshore* platformi i izbor položaja.
- Ekspertni sustavi u sustavima upravljanja – praćenje flote i upravljanje, vođenje broda, dinamičko pozicioniranje, integrirano upravljanje s mosta, itd.
- Ekspertni sustavi u sustavima nadzora i dijagnostike – nadzor glavnih i pomoćnih strojeva i opreme na brodu, dijagnostika rada i kvarova brodskih strojeva i uređaja, analiza performansi strojeva u eksploataciji i slično.
- Ekspertni sustavi u simuliranju i predviđanju – prognoze vremena i stanja mora, simuliranje brodskih procesa, predviđanje stanja strojeva i preventivno planiranje održavanja.
- Ekspertni sustavi u klasifikaciji – pravna regulativa u pomorstvu, zahtjevi klasifikacijskih društava.
- Ekspertni sustavi opće namjene – informacijski ekspertni sustav o raspoloživim resursima (materijalni, financijski, kadrovski i drugi.).
- Ekspertni sustavi u edukaciji.

Najviše su se razvili ekspertni sustavi za velike uređaje kao što su glavni porivni strojevi. Ekspertni sustavi se temelje na eksperimentalnim podacima dobivenim mjerenjem relevantnih značajki motora, koji se od strane proizvođača motora unose u bazu podataka, u kojoj su iskustvena, stručna saznanja eksperata.

Baza znanja pri izradi dijagnostičkog ekspertnog sustava je datoteka kvarova gdje se unose teorijska i praktična znanja stručnjaka. Osnovni zahtjevi koji se očekuju u radu stroja, pa tako i brodskoga dizelskog motora, jesu maksimalni radni učinci s minimalnim troškovima održavanja. Danas se ovim zahtjevima može udovoljiti samo uvođenjem novoga tehnološkog pristupa u praćenju i mjerenju radnih karakteristika stroja, uz korištenje računalnom tehnikom i znanošću u dijagnosticiranju i otklanjanju kvarova.



Slika 4. Ekspertni sustav upravljanja i dijagnostike brodskog pogonskog stroja [13]

Ekspertni sustavi za upravljanje i dijagnostiku brodskog pogonskog stroja u radu koriste osim signala dobivenih neposrednim mjerenjem s mjernih pretvornika – senzora, i pridodane baze znanja i simulacijske modele procesa, te mehanizme zaključivanja i odluke što im pruža nove mogućnosti dijagnostike, inteligentnog i adaptivnog upravljanja.

U pomorskom se prometu inteligentni transportni sustavi razlikuju po tehnologiji, aplikaciji i namjeni sustava. Danas se poznati sustavi kreću od osnovnih navigacijskih sustava, sustava za rukovanje kontejnerima, informacijskih sustava, pa sve do složenih sustava kao što su praćenje brodova, povratne informacije iz različitih izvora, meteorološke stanice, i sl. Osim navedenih, u razvoju je još više složenih sustava, kao što su sustavi koji kombiniraju nekoliko ciljanih sustava u jedinstveni sustav; sustav za rekonstrukciju pomorske nesreće i sl.

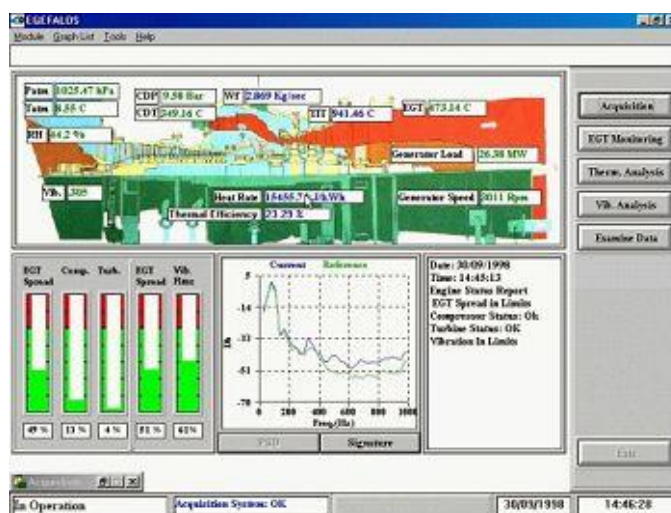
Razvoj novih sustava od presudne je važnosti, jer samo to pridonosi većoj učinkovitosti i

sigurnosti pomorskog prometa. U tu se svrhu u Europi razvila Europska agencija za pomorsku sigurnost (*European Maritime Safety Agency - EMSA*), koja ima osnovnu namijenjenu sprječavanja onečišćenja mora s brodova, te osiguranja pomorske sigurnosti i zaštite. Isto tako EMSA je odgovorna za pružanje usluga nadgledanja pomorskog prometa kroz sustave SafeSeaNet, CleanSeaNet i LRIT 1 (eng. *Long-Range Identification and Tracking of Ships*) koji su zaduženi za sprječavanje onečišćenja mora i morskog okoliša.

3.2. NAJZNAČAJNIJI EKSPERTNI SUSTAVI NA BRODOVIMA

Britanska tvrtka *Acoustic Technology Limited* razvila je računalni program za praćenje vibracija pogonskog motora. Korištenjem spomenutog programa mogu se predvidjeti eventualni kvarovi na stroju. Sustav praćenja vibracija i stanja stroja bazirano je na unaprijed definiranom konceptu. Program koristi zabilješke o održavanju i povijesti kvarova sličnih pogona da bi se definirali točni parametri za praćenje i odredila najefikasnija metoda analize podataka i prezentacija informacija.

Tvrtka Siemens AG 1976. godine proizvela je računalo koje služi za davanje dijagnoze o stanju motora. Cilj je bio izrada takvog sistema dijagnosticiranja koji obuhvaća i kontrolu kompletnog pogonskog uređaja.



Slika 5. Korisničko sučelje ENCOM ekspertnog sustava [16]

Ispitivanja su započela na pokusnom motoru tvrtke MAN tipa V65/65. Wärtsilä Diesel, jedna od vodećih tvornica dizel-motora, osamdesetih godina uvela je novi nadzorni sustav specijalno namijenjen dizel-motorima ENCOM (*Engine Condition Monitoring*) s naglaskom na pouzdanost i povećanu sigurnost. Tih godina objavljeno je niz radova i izvješća u kojima se razmatra nadzor i dijagnoza stanja motora.

Ekspertni sustavi za održavanje nastaju također osamdesetih godina razvojem tehnologije umjetne inteligencije, a predstavljaju novu etapu u tehnološkom razvoju praćenja stanja dizel-motora. To su računalni programi, koji djeluje kao inteligentna pomagala u rješavanju određenih problema. Baza znanja ekspertnog sustava je datoteka gdje se unose teoretska i praktična znanja eksperata. U spomenutom razdoblju *Lloyd Register* razvija sistem DECSP (*Diesel Engine Software Processor*) s ekspertnim sustavom dijagnoze kvara i karakteristike goriva uz simulaciju potrebnog održavanja.

Američka mornarica razvila je više pristupa održavanja. PIMS (*Phalanx Integrated Maintenance System*) je integrirani sustav održavanja razvijen da smanji zahtjeve za vremenom održavanja, poveća pristupačnost sustavu i osigura okvir za budućnost elektroničkom održavanju. PIMS kombinira ekspertni dijagnostički sustav, automatizirane postupke održavanja, automatski upisuje aktivnosti održavanja, itd.

Prijedlog za implementaciju procesa proaktivnog održavanja PaM (*Proactive Maintenance*) unutar američke mornarice usredotočen je na reduciranje koncepta održavanja i maksimiziranje vijeka strojeva putem sistematske identifikacije i eliminacije/ublažavanja korijenskih uzroka kvarova. Pristup koji je predložen zasniva se na principima održavanja usmjerenog na pouzdanost RCM (*Reliability Centred Maintenance*) i cjelovitom produktivnom održavanju TPM (*Total Productive Maintenance*). Dizajniran je da bude kompatibilan s ukupnom kvalitetom kontinuirane strategije održavanja – mornaričkog poslovnog poduzetničkog modela CMS-NBE (*Continuous Maintenance Strategy – Navy Business Enterprise Model*) i informatičkog integralnog sustava za utvrđivanje stanja ICAS (*Integrated Condition Assessment System*). PaM ili Living RCM analizira podatke, ističe potencijalni problem područja, istražuje rješenja i nudi novi pravac u nastojanju održavanja.

MAN B&W razvio je sustav računalnog nadzora rada motora CoCoS (*Computer Controlled Surveillance*) čime se omogućuje povećani nadzor, planiranje održavanje motora i identifikacija pričuvnih dijelova. Postoje četiri softverska programa:

- Program CoCoS EDS (*The Engine Diagnostics System*) obuhvaća bilježenje, nadzor i dijagnostiku. Ukoliko postoji odstupanje performanse ili kvar, dobit će se mogućnost uzroka kvara i koje radnje treba poduzeti da bi se kvar uklonio.
- CoCoS MPS (*The Maintenance Planning System*) daje podatke za cjelovito planiranje poslova održavanja, potrebnih rezervnih dijelova, alata, kao i predviđeno vrijeme za obavljanje određenog posla.
- CoCoS SPO (*The Stock and Spare Parts Ordering System*) omogućava optimizaciju pričuvnih dijelova, potrebne minimalne zalihe rezervnih dijelova, cijene, opskrbljivače.
- CoCoS SPC (*The Spare Parts Catalogue*) daje informaciju o pričuvnim dijelovima, potrebne crteže, skice, itd.

Sulzer je razvio sustav za dijagnostiku stanja brodskih motora pod nazivom MAPEX koji se koristi za optimizaciju rezervnih dijelova i održavanje. Baza podataka omogućava traženje bilo koje komponente, potrebne operacije, identifikaciju pričuvnih dijelova, pristupa održavanja, itd. Sulzer je u sklopu razvojnog projekta *Technology Demonstrator* primijenio elektroničko upravljanje i nadzor na motor.

Sve veći troškovi i složenost sustava u kombinaciji s kraćim ekonomskim vijekom trajanja proizvoda visoke tehnologije potiče analizu učinkovitosti sustava i troškova u vijeku trajanja. Posljednjih godina razvio se sustav upravljanja vijekom trajanja ili LCM – sustav (*Life Cycle Management*), kako bi se poboljšala kontrola logističkog procesa i postigla bolja troškovna učinkovitost ratnih brodova i sustava Nizozemske kraljevske ratne mornarice RNLN (*Royal Netherlands Navy*). Konceptija LCM – sustava sastoji se od definiranja, specificiranja, primjene i kontrole logističkog procesa. To se postiže metodom analiziranja koja je utemeljena na analizi logističke podrške LSA (*Logistic Support Analysis* – MIL-STD 1388-1A) i metodom programiranja zasnovanom na integralnoj logističkoj potpori ILS (*Integrated Logistic support*).

MAPEX je u biti nadogradnja na postojeći sustav elektronskog upravljanja DENIS (*Diesel Engine Control and Optimizing Specification*). MAPEX u prijevodu znači "Praćenje i poboljšavanje procesa održavanja sa znanjem eksperta i ima nekoliko inačica ovisno o funkciji. MAPEX-PR je sustav nadzora cilindara. Sustav je namijenjen velikim dvotaktnim motorima. Sustav kontinuirano prati radne uvjete u cilindru motora kao što su temperatura radne površine cilindarske košuljice, ulaznu i izlaznu temperaturu rashladne tekućine cilindara, temperaturu ispirog zraka nakon svakog rashladnika, mjeri broj okretaja motora i opterećenje motora. MAPEX – SM je sustav za održavanje i rezervne dijelove. Njegova svrha je planiranje održavanja, vođenja skladišta, praćenje količine dijelova na skladištu te naručivanje novih dijelova. [11]

4. ZAKLJUČAK

Ekspertni sustavi su, najjednostavnije rečeno, računalni programi koji sadrže određena specifična znanja iz jednog ili više određenih područja znanosti. Ovakvi programi su komercijalizirani posljednjih desetljeća 20. stoljeća.

Najčešći oblik ekspertnog sustava sastoji se od seta pravila po kojima se analiziraju informacije o specifičnoj vrsti problema, ali i pružanja matematičke analize problema. Ovisno o izvedbi, pružaju korisniku određene povratne informacije koje je potrebno poduzeti da bi se riješio zadani problem.

Na najvišoj razini, ekspertni sustav se može podijeliti na tri modula: bazu znanja, mehanizam zaključivanja i korisničko sučelje. Baza znanja sadrži specifično znanje o području primjene: činjenice, pravila i metode za rješavanje problema iz domene ekspertnog sustava. Mehanizam zaključivanja definira postupak pronalaženja rješenja problema kojeg je zadao korisnik, na temelju elemenata baze znanja. Korisničko sučelje omogućava korisniku uvid u postupak zaključivanja i proširivanje baze znanja.

Iako su ekspertni sustavi ostvarili manje nego je očekivano od njih, danas se razvijaju tehnologije kojima se poboljšavaju poznati nedostaci ekspertnih sustava. Primjerice, razvijaju se tehnike automatskog prikupljanja znanja, koriste se napredniji modeli koji se bave nesigurnošću i sve više se prelazi sa razvijanja sustava koji daju zaključke na razvoj sustava koji razgovaraju s korisnikom i na kraju daju preporuke umjesto jasnih naredbi. Očito je da se radom na razvoj ekspertnih sustava istovremeno razvija i veliki broj tehnologija umjetne inteligencije koje se bave upravljanjem znanjem.

Ekspertni sustavi svojom primjenom dostižu vrhunac tehnoloških procesa, te zbog neizbježnog razvoja novih tehnologija, potreban je kontinuiran razvoj istih, kako bi u doglednoj budućnosti mogli pratiti. Uz kombinaciju ekspertnih sustava i ostalih oblika umjetne inteligencije (npr. hibridnih sustava) povećavaju se i njihove mogućnosti a ekspertni sustavi sve više postaju korisni alati koji u svojim konkretnim područjima

primjene na jedan ili drugi način izvršavaju svoju primarnu ulogu – pomaganje ljudima i efikasnije obavljanje posla.

LITERATURA

- [1] Blažek, Ž., Meštrović, K: Inteligentni i ekspertni sustavi u elektroenergetici, Tehničko veleučilište u Zagrebu, Zagreb, 2015.
- [2] Poliščuk, J. E., Ekspertni sistemi, ETF Podgorica, dostupno na: <http://www.etf.ucg.ac.me> [22.5.2017.]
- [3] Cross, Thomas B: Knowledge Engineering, TECHtionary Corporation, 2016.
- [4] Jurić, Z., Račić, N., Radica, G: Ekspertni sustav inteligentnoga dizelskog motora, stručni članak, Naše more 52(1-2)/2005
- [5] Gold, H: Ekspertni sustavi u prometu, nastavni materijali, Sveučilište u Zagrebu, Fakultet prometnih znanosti, Zagreb, 2010.
- [6] <http://autopoiesis.foi.hr/wiki.php?name=KM+-+Tim+16&parent=NULL&page=Prikupljanje%20znanja%20za%20ekspertni%20sustav> [17.6.2017.]
- [7] Bosančić, B: Baze znanja *online* referentnih usluga, magistarski rad, Sveučilište u Zagrebu, Filozofski fakultet, Zagreb, 2009.
- [8] Čerić, V., Varga, M: Informacijska tehnologija u poslovanju, Element, Zagreb 2004.
- [9] Kosky, Ph., Balmer, R., Kea, W., Wise, G: Exploring Engineering, An Introduction to Engineering and Design, Elsevier, USA, 2013.
- [10] Manger, R., Softversko inženjerstvo, nastavni materijali, Sveučilište u Zagrebu, Prirodoslovno Matematički fakultet, Zagreb, 2012.
- [11] Šegulja, I., Bukša, A: Održavanje brodskog pogona, pregledni članak, Pomorstvo, god. 20, br. 2/2006, str. 105-118
- [12] Wikipedia, Programski jezik, https://hr.wikipedia.org/wiki/Programski_jezik [17.6.2017.]
- [13] Sustavi održavanja, nastavni materijali, <http://www.pfst.unist.hr/uploads/SUSTAVI%20ODRAVANJA.pdf> [17.6.2017.]
- [14] Što je ekspertni sustav?, http://www.zemris.fer.hr/predmeti/is/zadaci/AkGod2001_2002/GajsakSipkaJaksic/sto_expert.htm [17.6.2017.]
- [15] Šegvić, S: Inteligentni sustavi: Uvod u programski jezik PROLOG, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, Zagreb, 2000.

[16] InTech Open Science, <https://www.intechopen.com/books/progress-in-gas-turbine-performance/engine-condition-monitoring-and-diagnostics> [16.6.2017.]

POPIS ILUSTRACIJA

Slika 1. Jednostavan prikaz koncepta ekspertnog sustava	7
Slika 2. Detaljan prikaz koncepta ekspertnog sustava	8
Slika 3. Grafički prikaz multidisciplinarnog pristupa u izgradnji ekspertnih sustava ..	14
Slika 4. Ekspertni sustav upravljanja i dijagnostike brodskog pogonskog stroja	22
Slika 5. Korisničko sučelje ENCOM ekspertnog sustava	23